

基于加权纹理特征的 SAR 图像目标识别算法

张国刚^{1,2} 徐向辉¹

(1. 中国科学院电子学研究所 北京 100190; 2. 中国科学院大学 北京 100049)

摘要: 由于 SAR 图像与光学图像的显著差异, 光学图像的目标识别算法并不能应用到 SAR 图像中, 因此研究 SAR 图像的目标识别具有重要的意义。传统的基于模型的 SAR 图像目标识别算法中将所有的特征同等看待, 然而不同特征对于目标分类的贡献度可能差别很大。给不同的特征赋予不同的权重, 可能会改变目标在特征向量空间中的相对位置, 从而给出更合理的识别结果。采用 SAR 图像的纹理特征作为分类特征, 在支持向量机分类算法中加入使用 ReliefF 算法计算得到的特征权重。试验结果表明这种加权后的目标识别算法具有更高的目标识别率。

关键词: 合成孔径雷达; 目标识别; 纹理; 加权; 支持向量机

中图分类号: TN957.52 **文献标识码:** A **国家标准学科分类代码:** 510.4050

SAR image target recognition algorithms based on weighted texture features

Zhang Guogang^{1,2} Xu Xianghui¹

(1. Institute of Electronics, Chinese Academy of Sciences, Beijing 100190, China; 2. University of Chinese Academy of Science, Beijing 100049, China)

Abstract: Target recognition algorithms of optics images can't be applied to SAR images because of the prominent difference between SAR images and optics images, which makes the research to SAR image target recognition more important. Traditional recognition algorithms based on models pay same attention to all features by giving the same weight, whereas different features may have quite different influence to the recognition results. The relative positions of target projected to feature space may change by giving different features with different weights, which helps to get more appropriate recognition results. This article uses texture features as the recognition features, then the SVM algorithms is adopted with the feature weights calculated by ReliefF algorithm. The test results show that this weighted recognition algorithm has higher recognition rate.

Keywords: SAR; target recognition; texture; weighted; SVM

1 引言

合成孔径雷达(SAR)是一种工作在微波波段的相关成像雷达,它凭借其全天候、全天时、高分辨率、大面积的获取数据能力等突出优势成为当前遥感观测的重要手段。但随着 SAR 图像的大量获取,并且由于其与光学成像系统的显著差异,传统的人工 SAR 图像目标识别远远不能满足实际的需要,自动 SAR 图像目标识别技术已经成为当今的研究热点^[1]。

SAR 图像目标识别可以看成是一个多目标的分类问题^[2]。分类算法一般分为 3 个部分:特征提取、特征选择、分类算法选择。对于特征提取来说,传统的仅依靠 SAR

图像的灰度值进行信息提取的精度比较低,而由于 SAR 图像中含有的丰富的纹理信息,纹理特征越来越多地用于 SAR 图像信息提取。对于特征选择来说,传统的 SAR 图像目标识别算法并未考虑特征权重的影响,然而由于不同的纹理特征对于分类类别的相关度不同,这很有可能影响最后的识别结果,这就需要特征选择算法(比如信息增益率,ReliefF 算法等)给予不同的纹理特征不同的加权重,以提高分类的精度。对于分类算法来说,汪廷华等人^[3]提出了一种基于特征加重的支持向量机算法,其用特征选择算法计算得到的特征权重对核函数中的内积进行加权计算,从而避免了一些弱相关或不相关的特征在核函数的计算过程中起到支配性的作用,改善了传统支持向量

收稿日期:2015-03

机的分类精度。

利用 ReliefF 算法计算不同纹理特征对分类任务的重要程度,然后基于特征加权支持向量机算法对 SAR 图像的不同目标进行分类,将分类结果和传统的支持向量机结果进行比较,比较结果表明本文的方法具有更好的鲁棒性和分类能力。

2 基于灰度共生矩阵(GLCM)的纹理特征提取

灰度共生矩阵是像素距离和角度的矩阵函数,它通过计算图像中一定距离和一定方向的 2 点灰度之间的相关性,来反映图像在方向、间隔、变化幅度等空间分布特性。

定义方向为 θ , 间隔为 d 的灰度共生矩阵为 $p(i, j, d, \theta)$, $p(i, j, d, \theta)$ 表示矩阵 i 行 j 列的元素,其含义为灰度值为 i 的点 (m, n) 与灰度值为 j 的点 (k, l) 同时出现的概率。2 点之间的关系如下:

$$(k, l) = (m, n) + (d \cos \theta, d \sin \theta) \quad (1)$$

图像的纹理特征是在灰度共生矩阵的基础上计算出的一系列统计量,Haralick 等人根据灰度共生矩阵定义了包括角二阶矩、对比度、相关等 14 种纹理特征,但由于描述纹理的各统计量之间并不是完全独立的,因此无需采用所有的统计量来对 SAR 图像进行纹理特征提取。纹理特征的提取方法具体可以参考文献[4-5]。为了减少计算量,采用角二阶矩、对比度、相关度、熵、逆差矩 5 种统计量进行实验,它们的计算方法如下:

1)角二阶矩

$$ASM = \sum_i \sum_j p(i, j)^2 \quad (2)$$

2)对比度

$$COM = \sum_i \sum_j (i - j)^2 p(i, j) \quad (3)$$

3)相关度

$$CORR = \left[\sum_i \sum_j i \cdot j p(i, j) - u_x u_y \right] / \sigma_x \sigma_y \quad (4)$$

4)熵

$$ENT = - \sum_i \sum_j p(i, j) \log p(i, j) \quad (5)$$

5)逆差矩

$$IDM = \sum_i \sum_j p(i, j) / (1 + (i - j)^2) \quad (6)$$

在灰度共生矩阵的计算过程中,需要考虑的一个重要问题是选择合适的窗口。太小的窗口会导致无法有效地提取图像的纹理信息,而太大的窗口又会使得多种纹理信息掺杂在同一个窗口中。解决此问题的方法是在小规模的数据集上,多选择几个窗口进行实验,比较其效果,从中选择最合适的窗口来提取纹理信息。选择 8×8 的窗口进行 SAR 图像纹理特征提取。同时,需要计算窗口在 4 个方向($0^\circ, 45^\circ, 90^\circ, 135^\circ$)上的灰度共生矩阵,分别计算 4 个方向上的纹理特征统计量。由于 SAR 图像的纹理属于随机纹理特征,所以取 4 个方向纹理特征统计量的均值和方差作为分类所使用的特征。

3 特征加权算法——ReliefF 算法

不同特征与分类类别之间的相关性可能差别很大,某些特征可能与分类类别之间的相关性特别强,那么这些特征对于类别的表征性就比较强;相反,某些特征可能与类别之间的相关性特别弱,甚至与类别之间是统计独立的,那么这些特征对于类别的表征性就特别差。找到与分类类别相关性强的特征,有助于对整个分类问题的理解,并且在一定程度上可以减少计算量。计算各特征与类别之间的相关性强弱有多种方法,对于连续性变量特征来说,ReliefF 算法是比较有效的一种。

ReliefF 算法最早是由 Kononeill 提出的一种特征权重算法(feature weighting algorithms),该算法通过计算各个特征和类别的相关性强弱来给特征赋予不同的权重,然后将权重小于某个阈值的特征移除。ReliefF 算法的流程是每次从给定的训练样本集中随机选取一个样本 R ,然后从和 R 同类的样本集 H 和不同类的样本集 M 中分别找出 k 个最近邻样本,分别称为 near Hits 和 near Misses,用这些近邻样本来更新每个特征的权重,更新公式如下:

$$W(A) = W(A) - \sum_{j=1}^k diff(A, R, H_j) + \quad (7)$$

$$\left[\sum_{c \in class(R)} \frac{p(c)}{1 - ecclass(R)} \sum_{j=1}^k diff(A, R, M_j(c)) \right] / mk$$

式中: $W(A)$ 表示计算的权重, $M_j(C)$ 表示与 R 不同的类 C 中的第 j 个最近邻样本, $diff(A, R_1, R_2)$ 表示样本 R_1, R_2 在特征 A 上的差,其计算公式如下:

$$diff(A, R_1, R_2) = \begin{cases} \frac{|R_1[A] - R_2[A]|}{\max(A) - \min(A)}, & \text{连续} \\ 0, & \text{离散 } R_1[A] = R_2[A] \\ 1, & \text{离散 } R_1[A] \neq R_2[A] \end{cases} \quad (8)$$

从上面的公式可以看到,ReliefF 算法不仅适用于离散特征,还适用于连续特征,对于大部分特征选择算法来说,要将其应用到连续特征,需要先对其进行离散化处理,而 ReliefF 算法可以直接计算,这是 ReliefF 算法的突出优势。

4 特征加权支持向量机

支持向量机(support vector machine, SVM)是在 Vapnik 等人所建立的统计学习理论上发展起来的分类算法。该算法能够根据有限的样本信息在模型的复杂程度和学习能力之间寻求最佳折衷,因而特别适用于样本量小的情况,并且在泛化能力方面具有突出优势。SVM 广泛应用于图像分割[6]、图像目标检测[7]与目标识别[8]领域中。

SVM 的描述如下:假设一组带有类别标记的训练样本集合数据,样本的总个数为 l ,样本集表示为 $\{(x_1, y_1), \dots, (x_l, y_l)\} (x_i \in \mathbf{R}^n, y_i \in \{1, -1\})$ 可被超

平面 $\langle w, x \rangle + b = 0 (b \in \mathbf{R})$ 线性划分为 2 类。SVM 的目标是寻求最优的分类超平面使得分类间隔最大, 这等价于求解下面的二次规划问题:

$$\begin{aligned} \min_{w,b} \varphi(w) &= \frac{1}{2} \langle w, w \rangle \\ \text{s. t. } y_i (\langle w, x_i \rangle + b) &\geq 1 (i = 1, 2, \dots, l) \end{aligned} \quad (9)$$

求解上面的优化问题, 可以得到基于最优分类超平面的判决函数为:

$$f(x) = \text{sgn}(\langle w^*, x \rangle + b^*) = \text{sgn}\left(\sum_{i \in SV} y_i \alpha_i^* \langle x_i, x \rangle + b^*\right) \quad (10)$$

式中: SV 表示支持向量, $\alpha_i^* \geq 0$, 其是在求解优化问题时引入的。由于 α_i^* 大部分为 0, 使得支持向量的个数相对于训练样本来说比较少, 这使得支持向量机算法具有很高的计算速度和鲁棒性能。

很多时候, 原始特征空间中的训练数据属于线性不可分的情况, 解决此问题的方法是允许存在部分分类错误的样本, 这需要引入一个松弛变量 $\xi_i \geq 0 (i = 1, 2, \dots, l)$, 对应的优化问题变为:

$$\begin{aligned} \min_{w,b} \varphi(w) &= \frac{1}{2} \langle w, w \rangle + C \sum_{i=1}^l \xi_i \\ \text{s. t. } y_i (\langle w, x_i \rangle + b) &\geq 1 - \xi_i, (i = 1, 2, \dots, l) \end{aligned} \quad (11)$$

式中: $C > 0$ 为惩罚因子, 这个参数对于分类性能比较敏感, 其用于控制对错分样本的惩罚力度。

在上述优化问题的求解过程中, 可以发现计算原始特征空间中样本之间的内积是求解优化问题的关键。统计理论指出, 满足 Mercer 定理的函数 $K(x, y)$ 均可作为内积使用。这点为解决线性不可分的情况提供了一个开阔的思路。受此启发, 可以定义一个非线性映射 $\varphi: \mathbf{R}^n \rightarrow H$, 将数据映射到一个高维甚至是无限维的特征空间 H 中, 由于更高维度的空间天然具有更丰富的解释性能, 使得在特征空间 H 中去求解最优的分类超平面可能变得相对简单。在此过程中, 需要使用到函数 $k(x_i, x_j) = \varphi(x_i) \varphi(x_j)$, 称之为核函数, 它在支持向量机算法中起着举足轻重的作用。

然而, 在传统的支持向量机算法中并没有考虑各维度特征对分类结果的重要性程度。特征权重主要影响核函数的计算。核函数的作用是计算样本之间的内积, 而内积的计算需要样本的所有特征。而这些特征与分类结果相关性的差别可能是比较大的, 这有可能导致的一种后果就是一些弱相关或者不相关的特征在核函数的计算过程中起到决定性的作用, 从而影响分类的结果。因此, 在计算核函数的过程中考虑特征的权重是很有必要的。特征加权对于支持向量机算法的影响主要体现在核函数的计算当中^[3]。下面给出特征加权核函数的定义。

定义: 令 k 是定义在 $X \times X$ 上的核函数, $X \in \mathbf{R}^n$, P 是给定输入空间的 n 阶线性变换矩阵, 特征加权的核函数 k_p 定义为:

$$k_p(x_i, x_j) = k(x_i^T P, x_j^T P) \quad (12)$$

可见, 新的核函数在于引入了线性变换矩阵 P 。一般来说, 矩阵 P 取 n 阶对角阵。其对角线上的元素 $P_{ii} (1 \leq i \leq n)$ 代表第 i 个特征的权重。

下面列举一些常用的核函数加权后的形式。特征加权后的多项式核函数:

$$k_p(x_i, x_j) = (x_i^T P x_j^T P + 1)^d = (x_i^T P P^T x_j + 1)^d, d = 1, 2, \dots \quad (13)$$

特征加权后的 Gauss 径向基核函数:

$$k_p(x_i, x_j) = \exp\left(-\frac{|x_i^T P - x_j^T P|^2}{\sigma^2}\right) = \exp\left(-\frac{(x_i - x_j)^T P P^T (x_i - x_j)}{\sigma^2}\right) \quad (14)$$

特征加权后的 Sigmoid 核函数:

$$k_p(x_i, x_j) = \tanh(b(x_i^T P x_j^T P) + c) = \tanh(b(x_i^T P P^T x_j + c)), b > 0, c < 0 \quad (15)$$

特征加权支持向量机可以用以下的步骤构造:

步骤 1 收集带有类别标记的样本数据集和 S , S 由两部分 $\langle f, d \rangle$ 构成, f_s 为特征向量, $f_s = [f_{s1}, f_{s2}, \dots, f_{sn}]$, d 为类标号。

步骤 2 使用特征选择算法, 比如信息增益或者 ReliefF 算法来计算各个特征的加权系数, 构造特征权重向量 w 和线性变换矩阵 P , 如前所述 P 为对角阵。其中 w 和 P 计算方式如下:

$$P = \text{diag}(w) \quad (16)$$

$$w = (\sqrt{\text{weight}_1}, \sqrt{\text{weight}_2}, \dots, \sqrt{\text{weight}_n}) \quad (17)$$

步骤 3 选择一种加权后的核函数式, 用它替换标准 SVM 的核函数, 采用交叉验证等方法选用合适的模型参数构建分类器。

步骤 4 对分类器的性能进行评估。

5 实验结果与分析

该文选用郊区的 SAR 图像如图 1 所示。



图 1 郊区的 SAR 图像

此 SAR 图像中包含 3 类目标,居民点、水体和麦田,用上文介绍的方法来对此进行分析。实验的算法流程如下:

从图 1 所示的 SAR 图像中人工选择 3 类目标的样本,选取的样本数目分别为居民点样本 269 个,水体样本 231 个,麦田样本 216 个。

采用基于灰度共生矩阵的方法提取 SAR 图像的纹理特征,选取的窗口大小为 8×8 ,参数 d 设为 1。选取的特征为纹理特征统计量在 4 个方向上的期望和方差,具体表示为: $m_{ASM}, v_{ASM}, m_{COM}, v_{COM}, m_{CORR}, v_{CORR}, m_{ENT}, v_{ENT}, m_{IDM}, v_{IDM}$ 将所有的特征归一化到 $[0, 1]$ 区间。

利用 ReliefF 算法计算两两类别之间的特征权重系数,用其构造特征加权支持向量机的线性变换矩阵 P ,用支持向量机分类算法构造两两类别之间的分类器。这里不考虑多类问题。

评价分类器的性能,将特征加权支持向量机计算的目标识别率与传统支持相邻计算得到的结果进行对比,得出结论。

由 ReliefF 算法得到的特征权重的相对关系如下:对于居民点和水体两种类别来说,特征权重的相对关系为:

$$m_{IDM} > m_{COM} > m_{ENT} > v_{COM} > v_{IDM} > v_{ASM} > v_{ENT} > m_{ASM} > v_{CORR} > m_{CORR}$$

对于居民点和麦田两种类别来说,特征权重的相对关系为:

$$m_{COM} > v_{COM} > m_{IDM} > m_{ENT} > v_{IDM} > v_{ENT} > v_{ASM} > v_{CORR} > m_{CORR} > m_{ASM}$$

对于水体和麦田两种类别来说,特征权重的相对关系为:

$$m_{ASM} > v_{ASM} > v_{CORR} > m_{CORR} > m_{ENT} > m_{IDM} > m_{COM} > v_{COM} > v_{IDM} > v_{ENT}$$

可以看到对于不同的类别来说,特征权重的相对关系是不同的,理解这些相对关系可以加深对不同类别目标的理解。同时,可以忽略小于某个阈值的特征,以加快计算的速度,这对于一些实时性要求比较高的识别场景是很重要的。

假设居民点为类别 A,水体为类别 B,麦田为类别 C,分别构造 AB、AC、BC 3 个分类器,采用高斯径向基核函数,径向基核函数的参数选择方法可以参考文献[9-10]。采用 5-折交叉验证法估计其分类精度,2 种支持向量机算法得到的分类结果对比如表 1 所示。

表 1 2 种支持向量机的分类精度对比

类别	加权 SVM (%)	传统 SVM (%)	参数
AB	96.8	94.4	$C=3.125 \sigma=6.468$
AC	97.1	95.6	$C=3.750 \sigma=6.063$
BC	86.4	83.2	$C=1.150 \sigma=4.000$

从表 1 中可以看出,特征加权支持向量机的结果要优于传统支持向量机计算得到的结果。需要说明的是,分类参数

是由传统支持向量机的交叉验证得到的。为了对比,特征加权支持向量机使用相同的参数设置。另外,在特征加权支持向量机的计算过程中,忽略了特征权重为负的特征。

6 结论

在传统的 SAR 图像目标算法中,并未考虑不同特征对于目标识别的贡献率不同的因素,可能使得一些与目标识别相关性较差的特征在分类中起到决定性的作用。利用 ReliefF 特征选择算法计算不同特征对于目标识别的加权权重,并将其应用到改进的支持向量机算法中,取得了更高的目标识别率。同时,根据不同目标的加权重,可以加深对不同类别图像的理解,为了加快计算速度,可以只计算那些加权重大于某个阈值的特征,忽略对目标识别贡献率比较小的特征,而这非常适用于对实时性要求比较强的场合。总之,在 SAR 图像目标识别中,考虑特征权重的影响是很有意义的。

参考文献

- [1] Maitre H. 合成孔径雷达图像处理[M]. 孙洪译. 北京:电子工业出版社,2005.
- [2] 徐海祥. 基于支持向量机方法的图像分割与目标分类[D]. 武汉:华中科技大学,2005.
- [3] 汪廷华,田盛丰,黄厚宽. 特征加权支持向量机[J]. 电子与信息学报,2009,31(3):514-518.
- [4] 刘丽,匡刚要. 图像纹理特征提取方法综述[J]. 中国图像图形学报,2009,14(4):622-635.
- [5] 苏杰,王丙勤,郭立. 数字图像的纹理特征提取与分类研究[J]. 电子测量技术,2008,31(5):52-55.
- [6] 陈强,田杰,黄海宁,等. 基于统计和纹理特征的 SAS 图像 SVM 分割研究[J]. 仪器仪表学报,2013,34(6):1413-1420.
- [7] 刘松松,张辉,毛征,等. 基于 HRM 特征提取和 SVM 的目标检测方法[J]. 国外电子测量技术,2014,33(10):38-41.
- [8] 魏星. 基于 SVM 的山体滑坡灾害图像识别方法[J]. 电子测量技术,2013,36(8):65-70.
- [9] 林升梁,刘志. 基于 RBF 核函数的支持向量机参数选择[J]. 浙江工业大学学报,2007,35(2):163-167.
- [10] 周绍磊,廖剑,史贤俊. RBF-SVM 的核参数选择方法及其在故障诊断中的应用[J]. 电子测量与仪器学报,2014,28(3):240-246.

作者简介

张国刚,1989 年出生,硕士研究生。主要研究方向为 SAR 图像目标识别。

E-mail:woshifengne@sohu.com

徐向辉,研究员。主要研究方向为合成孔径雷达系统。